

基于混沌免疫粒子群优化和广义回归神经网络的 回采工作面瓦斯涌出量预测模型

王雨虹^{1*}, 付 华¹, 侯福营¹, 张 洋²

(1. 辽宁工程技术大学 电气与控制工程学院, 辽宁 葫芦岛 125105; 2. 辽宁工程技术大学 电子与信息工程学院, 辽宁 葫芦岛 125105)

(* 通信作者电子邮箱 yuhong0804001@126.com)

摘 要:为提高回采工作面绝对瓦斯涌出量预测的精度和效率,提出了将混沌免疫粒子群优化(CIPSO)算法与广义回归神经网络(GRNN)相耦合的绝对瓦斯涌出量预测模型。该方法采用CIPSO对GRNN的光滑因子进行动态优化调整,减少了人为因素对GRNN网络输出结果的影响,并采用优化后的网络建立瓦斯涌出量预测模型。通过对某煤矿瓦斯涌出量数据的仿真实验结果表明:基于CIPSO-GRNN的回采工作面绝对瓦斯涌出量模型比BP神经网络、Elman网络预测模型具有更好的预测精度和收敛速度,证明了该方法的有效性和可行性。

关键词:混沌免疫粒子群优化;广义回归神经网络;回采工作面;瓦斯涌出量

中图分类号: TP183 **文献标志码:** A

Gas emission prediction model of working face based on chaos immune particle swarm optimizations and generalized regression neural network

WANG Yuhong^{1*}, FU Hua¹, HOU Fuying¹, ZHANG Yang²

(1. School of Electrical and Control Engineering, Liaoning Technical University, Huludao Liaoning 125105, China;

2. School of Electronic and Information Engineering, Liaoning Technical University, Huludao Liaoning 125105, China)

Abstract: To improve the accuracy and efficiency of absolute gas emission prediction, a new algorithm based on Chaos Immune Particle Swarm Optimization (CIPSO) and General Regression Neural Network (GRNN) was proposed. In this algorithm, CIPSO was employed to dynamically optimize the smooth factor of GRNN to reduce the impact of artificial factors in GRNN model construction, and then the optimized network was adopted to establish gas emission prediction model. The simulation experiment results on gas emission data of a coal mine show that the model is of faster convergence and higher prediction accuracy than other prediction models based on BP and Elman neural network. It is proved that the proposed method is feasible and effective.

Key words: Chaos Immune Particle Swarm Optimization (CIPSO); General Regression Neural Network (GRNN); working face; gas emission quantity

0 引言

瓦斯涌出量是指在矿井开采过程中从煤与岩石内涌出的瓦斯量,瓦斯涌出是威胁煤矿安全生产的主要因素之一^[1],因此,对煤矿瓦斯涌出量的准确预测是防治瓦斯灾害的关键。

在煤矿开采过程中,瓦斯涌出量受到地质条件、煤层瓦斯含量、日进度、埋藏深度、煤层厚度及开采技术等多种因素影响,各因素间相互影响和制约,瓦斯涌出量与其影响因素之间呈现出高度复杂的非线性关系^[2]。因此,煤矿瓦斯涌出量具有参数时变性、多变量耦合性、非线性及不确定性等特点,很难对其涌出量大小实现精准的预测。近年来,许多专家学者将神经网络、支持向量机、灰色理论、分形理论等非线性预测方法应用到瓦斯涌出量预测中^[3-6],其中基于神经网络的瓦斯涌出量预测方法取得了一系列的研究成果,BP(Back Propagation)神经网络、径向基(Radial Basis Function, RBF)神经网络、Elman神经网络等算法都被广泛地应用。但通过研

究发现,采用上述神经网络算法建立的瓦斯涌出量预测模型都存在一定的缺陷:一方面,BP和RBF网络的参数不易确定,人为因素影响预测结果,降低了瓦斯涌出量预测精度;另一方面,虽然Elman神经网络的计算能力和网络稳定性较BP网络有所提高,但由于Elman自身网络结构复杂,使其存在学习速度慢、精度低和鲁棒性差的缺点,无法满足瓦斯涌出量预测精度和速度的需要。

广义回归神经网络(Generalized Regression Neural Network, GRNN)是建立在非参数回归基础上,具有结构稳定、收敛速度快、预测精度高、不易陷入局部极小值等优点,适合处理非线性预测问题^[7]。与BP、RBF和Elman神经网络相比,利用GRNN网络建立瓦斯涌出量预测模型主要有三方面优势:1)GRNN网络在非线性和学习速度上有很强的优势;2)由于煤矿生产条件恶劣,瓦斯涌出量数据中包含一定的噪声数据,而GRNN网络在样本量少而且噪声多时也能取得较好的预测效果;3)GRNN网络训练简单,仅需要对径向基

收稿日期:2014-05-22;修回日期:2014-07-28。

基金项目:国家自然科学基金资助项目(51274118);辽宁省科技攻关项目(2011229011)。

作者简介:王雨虹(1979-),女,辽宁阜新,讲师,博士研究生,主要研究方向:智能算法、智能检测监控;付华(1962-),女,辽宁阜新,教授,博士生导师,主要研究方向:信息处理、智能检测、智能控制;侯福营(1987-),男,山东菏泽人,硕士研究生,主要研究方向:机器学习、智能优化算法;张洋(1979-),男,辽宁葫芦岛人,讲师,博士研究生,主要研究方向:计算机系统仿真。

函数的光滑因子进行调整,预测速度较快。

本文提出了混沌免疫粒子群优化(Chaos Immune Particle Swarm Optimization, CIPSO)算法与 GRNN 相耦合建立回采工作面绝对瓦斯涌出量预测模型。该方法利用 CIPSO 优化 GRNN 网络中的光滑因子,克服原有瓦斯涌出量预测模型训练参数选取困难的缺陷,可提高预测精度和稳定性。

1 广义回归神经网络

GRNN 模型表达式为:

$$\hat{Y} = E(y | X) = \frac{\int_{-\infty}^{\infty} y f(X, y) dy}{\int_{-\infty}^{\infty} f(X, y) dy} \quad (1)$$

其中: \hat{Y} 是在输入 X 的条件下, y 的预测输出; y 是输出向量; X 是输入向量; $E[y | X]$ 是输出向量的期望值; $f(X, y)$ 为联合概率密度函数。

若联合概率密度函数 $f(X, y)$ 为高斯函数,则网络输出为:

$$\hat{Y} = \frac{\sum_{i=1}^n Y_i \exp\left(-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right)} \quad (2)$$

其中: X_i 、 Y_i 分别为第 i 个样本的输入和输出, σ 为光滑因子,其实质是高斯函数的标准差。

式(2)可简化为:

$$\hat{Y} = S_N / S_D \quad (3)$$

其中:

$$S_N = \sum_{i=1}^n Y_i P_i \quad (4)$$

$$S_D = \sum_{i=1}^n P_i \quad (5)$$

$$P_i = \exp\left(-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right) \quad (6)$$

根据 GRNN 的网络拓扑结构,建立包括输入层、模式层、求和层和输出层在内的瓦斯涌出量预测模型,其结构如图 1 所示。其中,输入层接收瓦斯涌出量样本数据输入,传递函数选用简单的线性函数;模式层为径向基层,传递函数一般为高斯函数,神经元个数等于训练样本个数;求和层的神经元分为两种,分别对模式层输出结果依据式(4)~(5)求解。输出层将求和层的两个结果按式(3)相除,得到最终的预测结果。




图 1 GRNN 结构

2 CIPSO-GRNN 模型

2.1 广义回归神经网络的光滑因子

GRNN 网络的形式不需要确定,只要训练样本确定,其拓扑结构和各神经元之间连接权值也随之确定,因此模式层中

核函数的光滑因子是唯一需要人工调节的参数。由式(2)可知,通过改变光滑因子 σ 的大小可以调整 GRNN 神经网络的各单元传输函数,以获得最佳的预测结果,因此选择合适的 σ 对提高网络的预测精度有重要的影响;若 σ 选择越大网络对样本的逼近性能越平滑,但 σ 过大会造成 GRNN 网络过拟合;相反, σ 越小网络越逼近样本,但 σ 太小会造成 GRNN 网络不收敛。目前,光滑因子 σ 的选取主要有两种方法,一种是利用手工调整的方法,但效率低且精度差;另一种方法是采用优化算法寻找最优的 σ 使 GRNN 网络误差最小。本文采用混沌免疫粒子群算法优化 GRNN 网络中的 σ 。

2.2 混沌免疫粒子群

目前应用到神经网络的优化方法主要有模拟退火算法、蚁群算法、遗传算法、粒子群算法等。粒子群优化(Particle Swarm Optimization, PSO)算法是一种模拟鸟类协作寻找食物的智能优化算法^[8],同遗传算法相比,PSO 算法具有操作简单、调整参数少且收敛速度快等优点。但 PSO 算法随着迭代次数的不断增加,在种群收敛集中的同时,各粒子也越来越相似,可能在局部最优解周围无法跳出。混沌免疫粒子群算法是将混沌算法和人工免疫系统中的克隆选择机制引入到标准粒子群算法中^[9],抗原为目标函数和约束条件,抗体为粒子群。为了提高种群的多样化程度,克隆和混沌变异时要选择亲和力高的抗体,按与其亲和力成正比的方式进行克隆,与亲和力成反比的方式进行混沌变异;将亲和力低的抗体按一定比例初始化。同标准粒子群算法相比较,CIPSO 算法利用克隆选择粒子,可使种群的收敛速度得到提升,对克隆后的粒子进行混沌变异,使种群容易跳出局部最优,提高种群的全局搜索能力。

本文采用 CIPSO 优化算法对 GRNN 的光滑因子 σ 进行优化搜索,使搜索到的 σ 满足 GRNN 的输出结果与目标期望结果的误差平方和最小。

2.3 混沌免疫粒子群相关参数

CIPSO 算法的相关参数主要包括适应度函数、种群大小、最大迭代次数和算法迭代终止条件等^[10]。

本文将 GRNN 的输出结果与目标期望结果的误差平方和作为适应度函数 J_i :

$$J_i = \sum_{i=1}^n (\hat{Y}(t) - Y(t, X))^2 \rightarrow \min \quad (7)$$

其中: $\hat{Y}(t)$ 为期望输出, $Y(t, X)$ 为 GRNN 网络输出, n 为实际样本数目。

CIPSO 种群大小会影响到算法的求解质量和求解的复杂度,若种群太大,种群的空间搜索能力增强,迭代次数减少,但适应度评估次数也会随之增加,计算量加大;若种群太小,则会使算法陷入局部收敛。通常在 CIPSO 算法中,种群大小为 20~50 为宜。

2.4 CIPSO-GRNN 模型的实现过程

1) 确定 CIPSO 算法的种群大小、适应阈值及最大迭代次数等参数;随机初始化种群,确定每一个粒子的起始速度和位置。

2) 将学习样本标准化处理后,连同粒子一起代入 GRNN 模型,按式(7)计算其适应度。比较第 i 个粒子通过全部位置时的适应度大小,以确定其最佳位置 P_{bi} ;比较全部粒子在其最佳位置 P_{bi} 的适应度值,确定整个种群的最佳位置 G_b 。

3) 判断是否达到算法终止条件,若满足,则停止计算,最优粒子的位置 G_b 即为光滑因子,代入式(3) 建立 GRNN 预测模型;不满足条件进行第 4) 步。

4) 根据每个粒子本身位置及最优粒子位置,结合式(8) ~ (9) 对粒子群速度和位置进行更新:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id} - x_{id}^k) + c_2 r_2 (P_{gd} - x_{id}^k) \quad (8)$$

$$x_{id}^{k+1} = x_{id}^k + V_{id}^{k+1} \quad (9)$$

其中: V_{id}^k 为第 k 次迭代粒子 i 的速度矢量的第 d 维分量; x_{id}^k 为第 k 次迭代粒子 i 的位置矢量的第 d 维分量; P_{id} 为粒子 i 个体极值 P_i 的第 d 维分量; P_{gd} 维全局极值 P_g 第 d 维分量; ω 为惯性权重; c_1 、 c_2 为学习因子; r_1 、 r_2 为在区间 $(0,1)$ 内变化的随机数。

5) 根据抗体、抗原亲和度对当前种群排序,精英克隆种群 S_k 由亲和度最高的粒子组成,其余粒子组成种群 L_k 。

6) 对 S_k 中的粒子进行克隆、混沌变异和选择操作,获得更新后的精英种群 S_{k+1} 。

7) 在 L_k 中,运用 $\Gamma(*)$ 算子对亲和度最低的粒子予以舍弃,得到新种群 L_{k+1} 。

$$\Gamma(X) = \text{rand}() (U - L) + L \quad (10)$$

其中: L 、 U 分别表示抗体粒子 X 取值范围的下界。

8) 将种群 S_{k+1} 和 L_{k+1} 合并,得到新一代种群 P_{k+1} 。

9) 检验是否满足终止条件,若不满足终止条件则返回第 3) 步。

2.5 CIPSO-GRNN 算法的时间复杂度

结合 2.4 节算法流程,分析 CIPSO-GRNN 模型在一次迭代过程中的时间复杂度。

假设种群大小为 N ,所解决问题的维数为 D ,第 1) 步初始化种群的时间复杂度为 $O(ND)$;第 2) 步所有粒子更新对应的时间复杂度为 $O(ND)$;第 3) 步和第 4) 步中的时间复杂度均为 $O(ND)$;第 5) 步中的时间复杂度为 $O(N \ln N)$;第 6) 步中,假设 S_k 中有 N_1 个粒子,经过克隆选择、变异的时间复杂度为 $O(N_1^2 D)$;第 7) 步中,假设 L_k 中有 N_2 个粒子,其中将 d

个亲和度较低的粒子舍弃,时间复杂度为 $O(d)$,其余进行克隆选择、变异,时间复杂度为 $O((N_2 - d)^2 D)$;第 8) 步中时间复杂度为 $O(1)$;第 9) 步中时间复杂度为 $O((N - d)^2 D)$ 。在上述分析中,算法每次迭代时间复杂度由 $O(ND)$ 、 $O(N \ln N)$ 、 $O(N_1^2 D)$ 和 $O((N - d)^2 D)$ 决定。因此,CIPSO-GRNN 模型的时间复杂度主要取决于种群大小、所解决问题的维度、被舍弃的粒子数量以及 CIPSO-GRNN 的迭代次数。

3 基于 CIPSO-GRNN 的瓦斯涌出量预测模型

3.1 影响瓦斯涌出量的主要因素

本文采用 CIPSO-GRNN 预测模型对某煤矿回采工作面的绝对瓦斯涌出量进行预测分析。回采煤工作面的瓦斯涌出包括两个部分:开采层的瓦斯涌出和邻近层的瓦斯涌出^[11]。通常情况下,来自开采层的瓦斯涌出量完全进入采煤工作面,而进入采煤工作面的邻近层瓦斯涌出量大小则与工作面的通风系统有关。即:

$$Q_{\text{CH}_4} = Q_B + C_i Q_L \quad (11)$$

其中: Q_{CH_4} 是采煤工作面绝对瓦斯涌出量; Q_B 是开采层绝对瓦斯涌出量; Q_L 是邻近层绝对瓦斯涌出量; C_i 是工作面通风系统的系数,当采空区保留有风巷时, $C_i = 0.2$;当采用煤体内巷道回风时, $C_i = 1$ 。结合该矿实际通风情况,选取 $C_i = 0.2$ 。

影响瓦斯涌出的因素众多,其中影响开采层瓦斯涌出量的因素包括煤层瓦斯含量、煤层倾角、工作面长度、煤层厚度、推进速度、煤层埋藏深度、开采厚度、采出率和开采强度等;邻近层瓦斯涌出量主要受邻近层瓦斯含量、邻近层厚度、层间距离、层间岩性、顶板管理方式等因素影响^[12]。考虑到采煤工作面的顶板管理方式均相同,故采用其他 13 个因素作为该矿瓦斯涌出量的主要因素。

利用文献[12]中的瓦斯涌出量数据进行训练和预测分析,该数据共 18 组,其中前 15 组作为训练样本,后 3 组用于测试。数据如表 1 所示。

表 1 回采工作面瓦斯涌出量与影响因素数据统计

样本序号	煤层深/m	煤层厚/m	瓦斯含量/ ($\text{m}^3 \cdot \text{t}^{-1}$)	层间距/m	推进速度/ ($\text{m} \cdot \text{d}^{-1}$)	开采强度/ ($\text{t} \cdot \text{d}^{-1}$)	煤层倾角/($^\circ$)	采高/m	工作面长/m	工作面采出率	邻近层瓦斯含量/ ($\text{m}^3 \cdot \text{t}^{-1}$)	邻近层厚/m	层间岩性	绝对瓦斯涌出量/ ($\text{m}^3 \cdot \text{min}^{-1}$)
1	408	2.0	1.92	20	4.42	1 825	10	2.0	155	0.960	2.02	1.50	5.03	3.34
2	411	2.0	2.15	22	4.16	1 527	8	2.0	140	0.950	2.10	1.21	4.87	2.97
3	420	1.8	2.14	19	4.13	1 751	11	1.8	175	0.950	2.64	1.62	4.75	3.56
4	432	2.3	2.58	17	4.67	2 078	10	2.3	145	0.950	2.40	1.48	4.91	3.62
5	453	2.2	2.40	20	4.51	2 104	15	2.2	160	0.940	2.55	1.75	4.63	4.17
6	516	2.8	3.22	12	3.45	2 242	13	2.8	180	0.930	2.21	1.72	4.78	4.60
7	527	2.5	2.80	11	3.28	1 979	17	2.5	180	0.940	2.81	1.81	4.51	4.92
8	531	2.9	3.35	13	3.68	2 288	9	2.9	165	0.930	1.88	1.42	4.82	4.78
9	550	2.9	3.61	14	4.02	2 352	12	2.9	155	0.920	2.12	1.60	4.83	5.23
10	563	3.0	3.68	12	3.53	2 410	11	3.0	175	0.940	3.11	1.46	4.53	5.56
11	590	5.9	4.21	18	2.85	3 139	8	5.9	170	0.795	3.40	1.50	4.77	7.24
12	604	6.2	4.03	16	2.64	3 354	9	6.2	180	0.812	3.15	1.80	4.70	7.80
13	607	6.1	4.34	17	2.77	3 087	9	6.1	165	0.785	3.02	1.74	4.62	7.68
14	634	6.5	4.80	15	2.92	3 620	12	6.5	175	0.773	2.98	1.92	4.55	8.51
15	640	6.3	4.67	15	2.75	3 412	11	6.3	175	0.802	2.56	1.75	4.60	7.95
16	450	2.2	2.43	16	4.32	1 996	12	2.2	160	0.950	2.00	1.70	4.84	4.06
17	544	2.7	3.16	13	3.81	2 207	11	2.7	165	0.930	2.30	1.80	4.90	4.92
18	629	6.4	4.62	19	2.80	3 456	13	6.4	170	0.803	3.35	1.61	4.63	8.04

3.2 建模过程及结果分析

基于 CIPSO-GRNN 的瓦斯涌出量预测模型分为离线建模和在线参数调整两个阶段。离线建模是利用训练样本数据确定神经网络的基本结构、参数和粒子群的种群数等;在线参数调整阶段是根据确定好的 CIPSO-GRNN 的基本结构进行瓦斯涌出量预测,并根据模型的输入、输出和误差信息,利用 CIPSO 算法对 GRNN 的光滑因子进行在线调整,以提高瓦斯涌出量预测的精度和实时性。

根据回采工作面瓦斯涌出量影响因素和 CIPSO-GRNN 网络特点,确定 GRNN 结构参数如下:输入层节点数 13,对应瓦斯涌出量的 13 个影响因素;输出层节点数为 1,对应瓦斯涌出量预测值。确定 CIPSO 算法参数粒子群大小为 20,加速因子 $c_1 = c_2 = 2$,最大迭代次数为 2000;随迭代次数的增加,惯性权重从 0.9 到 0.1 按线性规律变化,目标精度达到 10^{-4} 。

利用 Matlab 对基于 CIPSO-GRNN 瓦斯涌出量预测模型进行仿真实验,图 2 为某矿回采工作面绝对瓦斯涌出量实际值与预测值的对比曲线。从图 2 可看出,该模型具有良好的拟合精度,预测结果比较理想。

为了进一步说明 CIPSO-GRNN 模型的性能,表 2 将基于 CIPSO-GRNN 的瓦斯涌出量模型与文献[5,13]提出的瓦斯涌出量模型进行对比^[13]。为了定量分析模型的精度,选用平均相对误差 E_{MAPE} 作为评价标准,即:

$$E_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \times 100\% \quad (12)$$

从表 2 可看出:CIPSO-GRNN 预测算法的平均相对误差优于其他 4 种的预测算法,预测精度较高,用于回采工作面绝对瓦斯涌出量预测时,能获得较为准确的预测结果。




图 2 回采工作面绝对瓦斯涌出量实际值与预测值对比

表 2 常用瓦斯涌出量预测模型预测效果分析

样本序号	实际值	BP 神经网络		Elman 网络		最小二乘支持向量机		GRNN		CIPSO-GRNN	
		预测值	相对误差/%	预测值	相对误差/%	预测值	相对误差/%	预测值	相对误差/%	预测值	相对误差/%
16	4.06	4.8264	18.70	5.0224	23.70	3.8810	4.41	4.2375	4.37	4.1270	1.65
17	4.92	4.5283	7.96	5.1051	3.76	5.0303	2.24	4.6434	5.62	4.7452	3.55
18	8.04	8.1417	1.26	8.0580	0.22	8.0828	0.53	7.9373	1.28	7.9977	0.52
E_{MAPE}			9.31		9.23		2.39		3.75		1.91

图 3 是在相同训练次数下,CIPSO-GRNN、BP 和 Elman 网络的收敛程度对比。由图 3 可看出:基于 CIPSO-GRNN 预测模型的收敛精度比 Elman 模型高出近 1 个数量级,比 BP 模型高出近 2 个数量级,CIPSO-GRNN 预测模型具有很强的收敛效果。




图 3 3 种预测模型收敛曲线

4 结语

本文将擅长全局搜索的 CIPSO 算法与 GRNN 网络相耦合,利用 CIPSO 优化 GRNN 网络的光滑因子 σ ,避免了光滑因子选取的随意性,减少了人为因素对 GRNN 网络输出结果的影响,提高了 GRNN 网络收敛速度和精度。

建立基于 CIPSO-GRNN 算法的非线性系统预测模型,并将该模型应用于煤矿回采工作面的绝对瓦斯涌出量预测中。

通过对某矿区的绝对瓦斯涌出量预测实验表明,基于 CIPSO-GRNN 的瓦斯涌出量预测模型可以有效地实现对回采工作面绝对瓦斯涌出量的预测,其预测精度和收敛速度等都优于 BP 神经网络等其他预测模型。该方法为瓦斯涌出量这类非线性系统的预测研究提供了新的方法和思路,可以推广到其他领域。

在 CIPSO-GRNN 算法中,适应度函数对模型的准确度、时间复杂度等有着重要的影响,本文将误差的平方和作为 CIPSO-GRNN 算法的适应度函数,获得了更高的预测精度。在下一步工作中,将深入探讨适应度函数的选择和优化问题。

参考文献:

- [1] FUA H, SHAO L. Mine gas disaster features mining and the fusion prediction[M]. Beijing: Science Press, 2011. (付华, 邵良杉. 煤矿瓦斯灾害特征挖掘与融合预测[M]. 北京: 科学出版社, 2011).
- [2] HE L, SHI S, SONG Y, et al. Complexity and measurement of complex degree of gas gush heading faces of coal mine[J]. Journal of China Coal Society, 2008, 33(5): 547-550. (何利文, 施武亮, 宋译, 等. 回采工作面瓦斯涌出的复杂性及其度量[J]. 煤炭学报, 2008, 33(5): 547-550.)
- [3] PAN Y, DENG Y, ZHANG Q, et al. Gas emission prediction model based on QPSO-RBF[J]. China Safety Science Journal, 2012, 22(12): 29-34. (潘玉民, 邓永红, 张全柱, 等. 基于 QPSO-RBF 的瓦斯涌出量预测模型[J]. 中国安全科学学报, 2012, 22(12): 29

- 34).
- [4] FU H, XIE S, XU Y, *et al.* Study on MPSO-WLS-SVM-based mine gas emission prediction model[J]. *China Safety Science Journal*, 2013, 23(5): 56-61. (付华, 谢森, 徐耀松, 等. 基于 MPSO-WLS-SVM 的矿井瓦斯涌出量预测模型研究[J]. *中国安全科学学报*, 2013, 23(5): 56-61.)
 - [5] FU H, JIANG W, SHAN X. Study on coupling algorithm on coal mine gas emission forecast model[J]. *Journal of China Coal Society*, 2012, 37(4): 654-658. (付华, 姜伟, 单欣欣. 基于耦合算法的煤矿瓦斯涌出量预测模型研究[J]. *煤炭学报*, 2012, 37(4): 654-658.)
 - [6] XIAO P, LI S, SONG Y, *et al.* Prediction and grey-model building for gas emission in coal mines[J]. *Journal of Mining and Safety Engineering*, 2009, 26(3): 317-321. (肖鹏, 李树刚, 宋莹, 等. 瓦斯涌出量的灰色建模及其预测[J]. *采矿与安全工程学报*, 2009, 26(3): 317-321.)
 - [7] JIA Y, LU Q, SHANG Y. Rockburst prediction using particle swarm optimization algorithm and general regression neural network[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2013, 32(2): 343-348. (贾义鹏, 吕庆, 尚岳. 基于粒子群算法和广义回归神经网络的岩爆预测[J]. *岩土力学与工程学报*, 2013, 32(2): 343-348.)
 - [8] SU Y, SHEN J, ZHANG D, *et al.* Application of networks and improved PSO algorithms to earthquake prediction[J]. *Journal of Computer Applications*, 2011, 31(7): 1793-1796. (苏义鑫, 沈俊, 张丹红, 等. 神经网络和改进粒子群算法在地震预测中的应用[J]. *计算机应用*, 2011, 31(7): 1793-1796.)
 - [9] FU H, QIAO D, CHI J. CIPSO-ENN coupling algorithm for nonlinear dynamic system parameter identification[J]. *Journal of Xi'an Jiaotong University*, 2011, 45(2): 49-53. (付华, 乔德浩, 池继辉. 一种非线性系统参数辨识的耦合算法研究[J]. *西安交通大学学报*, 2011, 45(2): 49-53.)
 - [10] LIU J, GAO Y. Chaos particle swarm optimization algorithm[J]. *Journal of Computer Applications*, 2008, 28(2): 322-325. (刘军民, 高岳林. 混沌粒子群优化算法[J]. *计算机应用*, 2008, 28(2): 322-325.)
 - [11] SHI S, SONG Y, HE L, *et al.* Research on determination of chaotic characteristics of gas gush based on time series in excavation working face of coal mine[J]. *Journal of China Coal Society*, 2006, 31(6): 701-705. (施式亮, 宋译, 何利文, 等. 矿井掘进工作面瓦斯涌出量混沌特性判别研究[J]. *煤炭学报*, 2006, 31(6): 701-705.)
 - [12] ZHU H, CHANG W, ZHANG B. Different-source gas emission prediction model of working face based on BP artificial neural network and its application[J]. *Journal of China Coal Society*, 2007, 32(5): 504-508. (朱红青, 常文杰, 张彬. 回采工作面瓦斯涌出 BP 神经网络分源预测模型及应用[J]. *煤炭学报*, 2007, 32(5): 504-508.)
 - [13] SUN L, YANG S. Prediction for gas emission quantity of the working face based on LS-SVM[J]. *Journal of China Coal Society*, 2008, 33(12): 1377-1380. (孙林, 杨世元. 基于 LS-SVM 的回采工作面瓦斯涌出量预测[J]. *煤炭学报*, 2008, 33(12): 1377-1380.)
-
- (上接第 3347 页)
- [5] CAI S, XIA Z, ZHANG W. Semi-supervised spectral clustering of time-series similarity[J]. *Computer Engineering and Applications*, 2011, 47(31): 116-118. (蔡世玉, 夏战国, 张文涛. 时间序列相似性半监督谱聚类[J]. *计算机工程与应用*, 2011, 47(31): 116-118.)
 - [6] KALPAKIS K, GADA D, PUTTAGUNTA V. Distance measures for effective clustering of ARIMA time series[C]// *Proceedings of the 2001 IEEE International Conference on Data Mining*. Piscataway: IEEE Press, 2001: 273-280.
 - [7] ZHANG H, HO T, LIN M. A non-parametric wavelet feature extractor for time-series classification[C]// *KAKDD 2004: Proceedings of the 8th Pacific-Asia Conference*, LNCS 3056. Berlin: Springer-Verlag, 2004: 595-603.
 - [8] VAITHYANATHAN S, DOM B. Model-based hierarchical clustering[EB/OL]. [2010-10-10]. <http://arxiv.org/ftp/arxiv/papers/1301/1301.3899.pdf>.
 - [9] KANTELHARDT J W, ZSCHIEGNER S A, KOSCIELNY-BUNDE E, *et al.* Multifractal detrended fluctuation analysis of nonstationary time series[J]. *Physica A: Statistical Mechanics and its Applications*, 2002, 316(1/2/3/4): 87-114.
 - [10] ZHANG L, LIU C. Multifractal analysis of Japan and China stock markets in different economy Periods[J]. *Systems Engineering—Theory and Practice*, 2013, 33(2): 317-328. (张林, 刘春燕. 日中两国不同经济时期股市的多重分形分析[J]. *系统工程理论与实践*, 2013, 33(2): 317-328.)
 - [11] HUANG J, CHENG H, GUO Y, *et al.* Research on multifractal features of the relation between price and volume in China metal futures market: based on MF-DCCA approach[J]. *Management Review*, 2013, 25(4): 77-85. (黄健柏, 程慧, 郭尧琦, 等. 金属期货量价关系的多重分形特征研究——基于 MF-DCCA 方法[J]. *管理评论*, 2013, 25(4): 77-85.)
 - [12] NI Z, HU T, WU X, *et al.* A novel machine learning approach based on fractal theory: Fractal learning[J]. *Journal of University of Science and Technology of China*, 2013, 43(4): 265-270. (倪志伟, 胡汤磊, 吴晓璇, 等. 基于分形理论的一种新的机器学习方法: 分形学习[J]. *中国科学技术大学学报*, 2013, 43(4): 265-270.)
 - [13] HUANG C, WU Q, WU Z, *et al.* Clustering financial time series based on multi-fractal features of variance volatility[J]. *System Engineering*, 2006, 24(6): 100-103. (黄超, 吴清烈, 武忠, 等. 基于方差波动多重分形特征的金融时间序列聚类[J]. *系统工程*, 2006, 24(6): 100-103.)
 - [14] ZHONG W, GAO Q, CHENG Y. The clustering of financial time series based on wavelet and multi-fractal[J]. *Systems Engineering*, 2009, 27(3): 58-61. (钟维年, 高倩维, 陈燕玲. 基于小波和多重分形的金融时间序列聚类[J]. *系统工程*, 2009, 27(3): 58-61.)
 - [15] YIN Y, SHAN P. Modified DFA and DCCA approach for quantifying the multiscale correlation structure of financial markets[J]. *Physica A: Statistical Mechanics and its Applications*, 2013, 392(24): 6442-6457.